

Veleučilište u Šibeniku
Odjel menadžmenta
Specijalistički stručni studij menadžmenta

Marina Zorica

UTJECAJ EKONOMSKE KRIZE NA TRŽISTE OSOBNIH AUTOMOBILA
U REPUBLICI HRVATSKOJ; PRIMJENA NEMAPARAMETARSKIH
STATISTIČKIH METODA

Diplomski rad

Šibenik, lipanj, 2015.

Veleučilište u Šibeniku

Odjel menadžmenta

Specijalistički stručni studij menadžment

**UTJECAJ EKONOMSKE KRIZE NA TRŽISTE OSOBNIH
AUTOMOBILA U REPUBLICI HRVATSKOJ; PRIMJENA
NEMAPARAMETARSKIH STATISTIČKIH METODA**

Diplomski rad

Kolegij: Statistika

Mentor: Ana Perišić, univ. spec. oec.

Student(-ica): Marina Zorica

Broj indeksa: 14518 1371

Šibenik, lipanj, 2015.

Sadržaj

1. Uvod	1
2. Testiranje statističkih hipoteza	3
2.1. Pogreška tipa I.....	6
2.2. Pogreška tipa II.....	6
2.3. Empirijska razina signifikantnosti - P vrijednost	6
2.4. Testna statistika	7
2.5. Razina statističke značajnosti.....	7
2.6. Parametarski testovi.....	8
2.7. Neparametarski testovi	8
2.8. Usporedba parametarskih i neparametarskih testova.....	10
2.9. Wilcoxonov test (Wilcoxon one sample signed rank test)	10
2.10. Koeficijent korelacije ranga Spearmana	13
2.11. Hi kvadrat test.....	14
3. Automobilska industrija i utjecaj ekonomske krize.....	19
3.1. Trendovi razvoja autoindustrije u svijetu	21
3.2. Autoindustrija u Republici Hrvatskoj.....	23
4. Rezultati	27
4.1. Usporedba rangova automobilskih marki prije, poslije i za vrijeme trajanja krize.....	28
4.2. Usporedba prodaje automobila s obzirom na pogonsko gorivo.....	33
5. Zaključak.....	42
 Popis grafikona, slika i tablica.....	43
Literatura:	45

Veleučilište u Šibeniku
Odjel Menadžmenta
Specijalistički diplomski stručni studij Menadžment

Diplomski rad

**UTJECAJ EKONOMSKE KRIZE TRŽISTE OSOBNIH AUTOMOBILA U
REPUBLICI HRVATSKOJ; PRIMJENA NEMAPARAMETARSKIH STATISTIČKIH
METODA**

MARINA ZORICA

Rupe, Laškovića 13 A; marinazorica16@gmail.com

Sažetak

Automobilska industrija jedna je od najvećih i najvažnijih industrija u svijetu, a automobilske se kompanije ubrajaju među najsnažnije i najveće svjetske kompanije. Kako je ekonomska kriza zavládala cijelim svijetom tako je utjecala i na automobilsku industriju. U radu se analizira prodaja četrdeset i dvije marke automobila s aspekta prije i nakon posljednje svjetske ekonomske i financijske krize, osim toga analizira se prodaja automobila s obzirom na pogonsko gorivo. Cilj ovog rada bio je ispitati utjecaj ekonomske krize na tržište osobnih automobila Republici Hrvatskoj. U radu su analizirani podaci vezani uz broj novoregistriranih automobila po pojedinoj marki, te udio novoregistriranih automobila s obzirom na pogonsko gorivo (dizel ili benzin) unutar pojedine marke. Primjenom korelacijske analize i odgovarajućih neparametarskih statističkih testova (Wilcoxonov test na osnovi ekvivalentnih parova, hi kvadrat test) pokazano je kako ne postoji statistički značajna razlika u rangovima automobilskih marki, niti u distribuciji udjela novoregistriranih automobila s obzirom na pogonsko gorivo, prije i poslije prijelomne 2008. godine. Stoga se može zaključiti kako su unatoč krizi, rangovi automobilskih marki na hrvatskom tržištu ostali stabilni, to jest da se preferencije kupaca nisu promijenile unatoč krizi.

(48 stranica / 2 slike / 11 tablica / 9 grafikona / 44 literaturnih navoda / jezik izvornika: hrvatski)

Rad je pohranjen u: Knjižnici Veleučilišta u Šibeniku

Ključne riječi: neparametarska statistika, automobilska industrija, kriza, Hrvatska

Mentor: Ana Perišić, dipl.ing.mat, univ.spec.oec.

Rad je prihvaćen za obranu:.

**IMPACT OF THE GLOBAL ECONOMIC CRISIS ON THE AUTOMOTIVE
MARKET IN REPUBLIC OF CROATIA; AN APPLICATION OF
NONPARAMETRIC STATISTICAL METHODS**

MARINA ZORICA

Rupe, Laškovica 13 A; marinazorica16@gmail.com

Abstract

The automotive industry is one of the largest and most important industries in the world. Automotive companies are among the strongest and largest global companies. As the economic crisis gripped the entire world, it also influenced on the automotive industry. This paper analyzes the number of newly registered cars for forty-two manufacturers before and after the recent global economic and financial crisis. Furthermore, the number of newly registered cars was analyzed due to the motor fuel. The aim of this study was to investigate the impact of the economic crisis on the car market in Croatia. The paper analyzes data related to the number of newly registered cars by individual manufacturer, and the share of newly registered cars due to the motor fuel (diesel or gasoline) within each manufacturer. By using correlation analysis and corresponding non-parametric statistical tests (Wilcoxon test, chi-square test) it is showed that there is no statistically significant difference in the ranks of car brands, nor in the distribution of shares of newly registered cars in view of the fuel before and after the break year 2008. Therefore, it can be concluded that despite the crisis, ranks automotive brands on the Croatian market remained stable, that is to customer preferences have not changed despite the crisis.

(41 pages / 2 figures / 11 tables / 9 graphs/ 44 references / original in Croatian language)

Paper deposited in: Library of Polytechnic in Šibenik

Keywords: nonparametric statistics, automotive industry, global crisis, Croatia

Supervisor: Mentor: Ana Perišić, dipl.ing.mat, univ.spec.oec..

Paper accepted:

1. Uvod

Današnji moderni svijet se ne može zamisliti bez revolucionarnog industrijskog proizvoda – automobila. Riječ automobil je grčko – latinskog podrijetla, ali se posve udomačio u hrvatskom jeziku. Definicija automobila je jednostavna: to je vozilo koje se bez uporabe tračnica pokreće snagom vlastitog motora, a prvo vozilo razvijeno je 1885. godine. Automobilska industrija jedna je od najvećih i najvažnijih industrija u svijetu, a automobilske se kompanije ubrajaju među najsnažnije i najveće svjetske kompanije.

Autoindustrija jedna je od predvodnica procesa globalizacije. Iako globalizacija nije novoga datuma, nego seže daleko u prošlost, tek su nove politike i tehnologije posljednjih nekoliko desetljeća dovele do ubrzanja i produbljivanja globalne međuovisnosti i integracije. Svijet je zahvatio novi val globalizacije u kojemu su tržišta roba, usluga, rada i kapitala sve jače međunarodno integrirana. Međunarodna trgovina, inozemna izravna ulaganja, međunarodna portfolio ulaganja i međunarodno kreditiranje rastu brže od svjetske proizvodnje.¹

Kako je cijeli svijet zahvatila kriza, tako je zahvatila i automobilsku industriju. Kriza se prvenstveno se osjetila u SAD-u. Kriza utječe na apsolutno sve sektore povezane sa automobilskom industrijom, dolazi do pada izvoza, a najveći problem predstavljaju teški kreditni uvjeti.

Zahvaljujući statističkim metodama mogu se grafički prikazati i brojčano opisati podatci koji ukazuju na razmjer utjecaja globalne krize; zatim analiziranjem podataka mogu se donositi zaključci, kako bi se saznao način i uz koja ulaganja se mogu poboljšati poslovni procesi i rezultati poslovanja, te kako bi se donijele što točnije poslovne prognoze. Dobro analizirani podaci vrijedan su izvor prihoda. Oni mogu dovesti do novih otkrića i komercijalnih prednosti.

Predmet ovoga rada je analiza utjecaja krize na automobilsku industriju u Republici Hrvatskoj. Cilj rada bio je analizirati promjene u broju novoregistriranih automobila s obzirom na proizvođača i pogonsko gorivo u razdoblju prije i nakon prijelomne 2008./2009. godine. Ispitano je jesu li se promijenili rangovi novoregistriranih automobila prema proizvođaču u razdoblju prije krize u odnosu na razdoblje poslije (i za vrijeme) krize. Te je

¹ Grgić, M. i Bilas, V. 2008. Međunarodna ekonomija. Zagreb: Lares plus

analizirana razlika u udjelu novoregistriranih automobila s obzirom na pogonsko gorivo prema proizvođaču. U tu svrhu provedeni su neparametarski testovi i to Wilcoxonov test na osnovi ekvivalentnih parova i hi-kvadrat test. Rad je podijeljen u 5 dijelova i pisan je indikacijko-dedukcijskom metodom.

Nakon prvog, uvodnog dijela, u drugom dijelu rada, detaljno su opisane statističke metode korištene u radu. Definirani osnovni pojmovi vezani uz testiranje hipoteza, te je prikazan postupak testiranja. Poseban naglasak stavljen je na neparametarske testove i to Wilcoxonov test na osnovi ekvivalentnih parova i hi-kvadarat test. Nadalje, opisan je potupak provođenja korelacijske analize i to na temelju neparametarske inačice koeficijenta korelacije Spearmanovog koeficijenta korelacije.

U trećem dijelu opisan je razvoj automobilske industrije, trendovi razvoja autoindustrije u svijetu, te tržište automobila u Hrvatskoj. Dana je usporedba broja novoregistriranih automobila u Hrvatskoj s obzirom na marku automobila i usporedba broja novoregistriranih automobila s obzirom na pogonsko gorivo.

U četvrtom dijelu rada dani su rezultati provedenih analiza, dok su petom, zadnjem dijelu, dana zaključna razmatranja.

2. Testiranje statističkih hipoteza

Testiranje statističkih hipoteza je postupak koji uključuje formuliranje statističke hipoteze i upotrebu podataka iz uzorka, kako bi se moglo odlučiti o ispravnosti formulirane statističke hipoteze. Statistička hipoteza izraz koji predstavlja polaznu osnovu na kojoj se temelji kalkulacija statističkog testa. Takve hipoteze izvedene su iz znanstvenih hipoteza koje predstavljaju pretpostavke koje motiviraju istraživača.²

Testiranje statističkih hipoteza je postupak ili pravilo kojim se donosi odluka o odbacivanju ili neodbacivanju tvrdnje na temelju podataka iz slučajnog uzorka. Svako testiranje polazi od nulte hipoteze i alternativne hipoteze, a istraživač određuje sadržaj hipoteza. U alternativnoj hipotezi (H_1) zapisana pretpostavka je suprotna onoj u nultoj hipotezi (H_0). Drugim riječima, sadržaj alternativne hipoteze uvijek je suprotna sadržaju nulte hipoteze.

Prilikom testiranja hipoteza statističari izbjegavaju donositi apsolutne i u potpunosti neporecive zaključke upravo iz razloga jer se testiranje hipoteza temelji na pokazateljima uzorka. Dakle, ne donose se egzaktni zaključci po kojima se nulta hipoteza prihvaća, već se radije zaključuje kako se nulta hipoteza ne može odbaciti zbog toga što je apsolutno prihvaćanje i odbacivanje hipoteza dopušteno samo ako se odluka temelji na podacima cjelokupne populacije, a ti podaci su često nedostupni i/ili skupi za prikupljanje.³

Sud koji izvire iz odluke o prihvaćanju ili neprihvatanju nulte hipoteze nije kategoričan jer se odluka donosi na temelju vrijednosti iz slučajnog uzorka, odnosno dijela podataka.⁴ Razlikuju se testiranja provedena na temelju podataka jednog uzorka iz jedne populacije ili na temelju dva, odnosno više uzoraka iz dviju ili više populacija. Ovisno o smjeru testiranja razlikuju se testiranja temeljena na pokazateljima jednog uzorka odnosno na pokazateljima dvaju ili više uzoraka.⁵

Budući da se istraživanje provodi na uzorku, a ne na cijeloj populaciji, moguće je prilikom donošenja odluke učiniti grešku. Istraživači posebnu pozornost posvećuju pogreškama čije se pojavljivanje očekuje i predviđa u postupcima testiranja i odlučivanja. U postupku testiranja hipoteza donose se dvije vrste odluka: odbaciti ili ne odbaciti nultu hipotezu. Zaključak o odbacivanju ili neodbacivanju statističke hipoteze rezultat je rada s jednim ili više uzoraka.

² <http://oliver.efri.hr/~statist/biljan-pivac-stambuk-sa-4-hipoteze.pdf>

³ Horvat J.; Mijoč J.; "Osnove statistike", str. 338., Ljevak, Zagreb, svibanj 2012. godine

⁴ Šošić I.; "Primijenjena statistika", str. 237., Školska knjiga, Zagreb, 2004. godina

⁵ Horvat J.; Mijoč J.; "Osnove statistike", str. 339., Ljevak, Zagreb, svibanj 2012. godine

Najčešće se testira hipoteza o nepoznatoj aritmetičkoj sredini osnovnog skupa.⁶ Iako detalji testiranja mogu varirati od testa do testa, za svako testiranje statističkih hipoteza Postupak se koristi u četiri koraka:

Korak 1: Postavljanje hipoteza

U prvom koraku zapisuju se nulta i alternativna hipoteza koju istraživač postavlja kao tvrdnje. Na primjer, prilikom testiranja hipoteze o parametru, u skladu s istraživanjem, odlučuje se je li riječ o dvosmjernom ili jednosmjernom testiranju koje će se provesti za jednu ili dvije populacije. Kod dvosmjernog testa nulta hipoteza navodi da je stvarna vrijednost parametra jednaka pretpostavljenoj vrijednosti dok alternativna hipoteza nijeće ovu relaciju. Kod jednosmjernog testiranja jedne populacije, utvrđuje se koja je vrsta jednosmjernog testa potrebna (na gornju ili donju granicu).

Korak 2: Odabir razine značajnosti α

Uglavnom se prethodno provođenju statističkih testova odabire razina značajnosti (razina signifikantnosti) α . Najčešće razine značajnosti koje ispitivač izabire su 1%, 5% i 10%. Razinu signifikantnosti možemo interpretirati kao najveću dopuštenu vjerojatnost odbacivanja istinite nulte hipoteze.

Korak 3: Odabir statističkog testa

Na temelju karakteristika populacija i samog istraživanja potrebno je odabrati test iz skupa neparametarskih i parametarskih testova. Kod testiranja hipoteze o parametru ključna su tri pokazatelja koja odlučuju o izboru statističkog testa. Ti pokazatelji su:

- veličina uzorka;
- standardna devijacija populacije σ
- smjer testiranja hipoteza.

Pri testiranju hipoteze o parametru, ovisno o veličini uzorka odabire se z -test (za velike uzorke gdje je $n \geq 30$) ili t -test (za mali uzorak gdje je $n < 30$). Testiranje hipoteze o parametru ovisi i o poznavanju standardne devijacije populacije σ koja je gotovo uvijek nepoznata veličina pa se koristi standardna devijacija iz prethodnih istraživanja ili se procjenjuje na temelju standardne devijacije uzorka. Odabir statističkih testova ovisi i o smjeru testiranja hipoteza. Kod dvosmjernih testova izračunavaju se obje granice područja (ne)odbacivanja nulte

⁶ Žužul Josip, Branica Marija, Statistika, Informator, Zagreb, 1998.

hipoteze (i gornja i donja granica) dok se kod jednosmjernih testova izračunava samo jedna od granica (test na gornju ili na donju granicu).⁷

Korak 4: Izračunavanje test veličine i donošenje odluke o nultoj hipotezi

Test veličina je numerički rezultat statističkog testa odnosno kriterij na osnovu kojeg se provodi testiranje. U ovisnosti o prirodi i veličini uzorka te o samoj hipotezi koriste se različite testne statistike. Tako se testovi vezani uz testiranje hipoteze o parametrima osnovnih skupova kao što su aritmetička sredina i proporcija oslanjaju na z-testove i t-testove koji u omjer stavljaju razliku između empirijske i teorijske procjene parametra i standardne pogreške procjene. Kod neparametarskih testova u omjer se stavljaju i razlike između empirijske i teorijske frekvencije i empirijske frakvencije itd.

Hoće li se nulta hipoteza odbaciti ili neodbaciti moguće je odrediti usporedbom testne veličine i kritične granice ili na temelju pripadne p-vrijednosti. Odluka o nultoj hipotezi uvijek rezultira odabirom jedne od dviju odluka⁸:

- nulta hipoteza se odbacuje ili
- nulta hipoteza se ne odbacuje.

Veličina empirijske razine signifikantnosti sastavni je dio rezultata obrade pomoću računala koji se odnose na test određene hipoteze. Pri zaključivanju pomoću p-vrijednosti nužno je imati na umu da ta vrijednost izvire iz rezultata uzorka, to jest da njezina kakvoća ovisi o kakvoći uzorka. Stoga je pri tumačenju rezultata potrebno uzeti u obzir i druge analitičke rezultate. Odluka o odbacivanju odnosno neodbacivanju hipoteze može se donijeti i na temelju usporedbe vrijednosti testne statistike i kritične vrijednosti. Kritična vrijednost se očitava iz tablica distribucije vezanih uz test.

⁷ Horvat J.; Mijoč J.; "Osnove statistike", str. 413, Ljevak, Zagreb, svibanj 2012. godine.

⁸ Horvat J.; Mijoč J.; "Osnove statistike", str. 414., Ljevak, Zagreb, svibanj 2012. godine

Tablica 1: Postupak testiranja i njegovi ishodi

Odluka	Nulta hipoteza je	
	Istinita	Lažna
Ne odbaciti nultu hipotezu	odluka ispravna	pogreška tipa II.
Odbaciti nultu hipotezu	pogreška tipa I.	odluka ispravna

Izvor: Šošić I., "Primijenjena statistika", str. 237., Školska knjiga, Zagreb, 2004. Godina

2.1. Pogreška tipa I

Pogreška I se događa u slučaju kada „se vidi” učinak kojeg zapravo nema. Vjerojatnost da će se napraviti pogreška tipa I obično se označava grčkim slovom α i njena se vrijednost uglavnom određuje prije testiranja statističke hipoteze. α još se naziva i „razinom značajnosti” i njena je vrijednost najčešće postavljena na 0,1, 0,05 ili 0,01. Kada je p vrijednost, dobivena u trećem koraku općih uputa o postupku testiranja statističke hipoteze, niža od vrijednosti α , nulta hipoteza se odbacuje, a njen se rezultat naziva „statistički značajnim na razini α ”.

2.2. Pogreška tipa II

Pogreška tipa II događa se kada se ne „vidi” razlika, a ona je zapravo prisutna. Vjerojatnost da će se napraviti pogreška tipa II naziva se beta β i njena vrijednost uvelike ovisi o veličini učinka koji zanima ispitivača, veličini uzorka i odabranoj razini statističke značajnosti. Beta se povezuje sa snagom testa u otkrivanju učinka navedene veličine.

2.3. Empirijska razina signifikantnosti - P vrijednost

P vrijednost se često pogrešno interpretira kao vjerojatnost da je nulta hipoteza istinita. Nulta hipoteza nije nasumična te ona nema vjerojatnosti. Ona je ili istinita ili nije. Pravo značenje P vrijednosti jest, da je to vjerojatnost odbacivanja istinite nulte hipoteze (uz dane vrijednosti uzorka) kada je nulta hipoteza istinita. Teorijska razina signifikantnosti α predodređuje odabranu vjerojatnost odbacivanja istinite nulte hipoteze dok empirijska ili opažena razina signifikantnosti (p-vrijednost) je vjerojatnost odbacivanja istinite nulte hipoteze izračunane

pomoću podataka iz uzorka odnosno test-veliĉine. P-vrijednost je mjera kojom se mjeri stupanj diskreditiranja nulte hipoteze na osnovi informacija sadržanih u uzorku. Postupak donošenja odluke na temelju p-vrijednosti glasi: ako je p-vrijednost *veća* od α , prihvaća se nulta hipoteza, a ako je p-vrijednost *manja* od α , odbacuje se nulta hipoteza.⁹

Tablica 2: Pravila odlučivanja na temelju P-vrijednosti

Test-veliĉina		Razina znaĉajnosti	Odluka o nultoj hipotezi - H_0
p-vrijednost	$\leq \alpha$	α	odbacuje se H_0
p-vrijednost	$> \alpha$	α	ne odbacuje se H_0

Izvor: Horvat J.; Mijoĉ J.; "Osnove statistike", str. 382., Ljevak, Zagreb, svibanj 2012. Godine

2.4. Testna statistika

Testna statistika je kriterij na osnovu kojeg se provodi testiranje. U ovisnosti o prirodi i veliĉini uzorka te o samoj hipotezi koriste se različite testne statistike. Tako se testovi vezani uz testiranje hipoteze o parametrima osnovnih skupova kao što su aritmetička sredina i proporcija oslanjaju na z-testove i t-testove¹⁰ koji u omjer stavljaju razliku između empirijske i teorijske procjene parametra i standardne pogreške procjene. Nadalje, testiranje o distribuciji osnovnog skupa moguće je provesti pomoću hi kvadrat test koji u omjer stavlja kvadrat razlike apsolutnih empirijskih frekvencija¹¹ i apsolutnih teorijskih frekvencija s apsolutnom empirijskom, odnosno uzoraĉkom, frekvencijom (testiranje hi-kvadrat testom).

Kod testiranja pretpostavki o vrijednosti parametara osnovnog skupa, testna statistika je nepristrana procjena parametra ili neka transformacija te procjene. Ona je slučajna varijabla koja poprima odreĉeni oblik distribucije vjerojatnosti.

2.5. Razina statističke znaĉajnosti

Važno je naglasiti da je razina statističke znaĉajnosti proizvoljna vrijednost koja se odabire kao graniĉna vrijednost u odlučivanju o nultoj hipotezi. Ćak i ako se zna toĉna P vrijednost,

⁹ Šošić I.; "Primijenjena statistika", str. 248., Školska knjiga, Zagreb, 2004. godina

¹⁰ Z-test koristi se za velike uzorke ($n > 30$), a t-test za male uzorke ($n \leq 30$)

¹¹ Frekvencija je broj podataka istog (ponekad i sliĉnog) obilježja varijable

potrebna je pomoć pri odlučivanju na temelju promatrane P vrijednosti. Prihvatljivo i jednostavno rješenje je ustanoviti posljedice pogrešnih odluka, odnosno pogrešaka tipa I i II. Ako (pogrešno) uočavanje razlike koje zapravo nema može naštetiti populaciji koju ispituje (ili općenito, svojoj populaciji), tada treba odabrati nižu razinu statističke značajnosti, odnosno pokušati smanjiti vjerojatnost pogreške tipa I.

2.6. Parametarski testovi

Testiranje hipoteza o parametrima osnovnih skupova pomoću uzoraka temelji se na određenim teorijskim pretpostavkama koje se npr. odnose na oblik distribucije osnovnog skupa. Vrlo često se pretpostavlja da slučajni uzorak vrijednosti numeričke varijable potječe iz normalne distribucije ili neke distribucije poznatih općih karakteristika, a odstupanje od tih teorijskih pretpostavki ugrožava valjanost zaključaka dobivenih postupkom testiranja. T-test, z-test, F-test i drugi testovi su parametarski testovi jer su u svezi s parametrima osnovnih skupova pretpostavljenog oblika.¹² Kod parametarskih testova primjeri parametara koji se koriste kada se primjenjuje normalna distribucija su varijanca i standardna pogreška. Pri provođenju parametarskih testova polazi se od danog oblika i karakteristika distribucije numeričke varijable u osnovnom skupu, odnosno od osobitosti sampling-distribucije.¹³ Parametarski testovi imaju veću statističku snagu koja se odnosi na vjerojatnost da će statistički test odbaciti lažnu nultu hipotezu.¹⁴

2.7. Neparametarski testovi

Neparametarski testovi se još nazivaju i "statistika slobodna od distribucije" (*distribution free tests*) koji se usredotočuju na činjenicu da je nepoznata sampling-distribucija i da nema pretpostavke o obliku distribucije parametara.¹⁵ Kada distribucija osnovnog skupa nije poznata ili nije npr. u obliku normalne distribucije, kada su podaci koji čine uzorak kvalitativni i mjereni na nominalnoj ili ordinalnoj skali, tada se ne mogu primijeniti postupci testiranja hipoteza o parametru. Testiranja hipoteza koje ne počivaju na potpunoj specifikaciji distribucije osnovnog skupa u sklopu su neparametarske statistike. Neparametarski testovi

¹² Šošić I.; "Primijenjena statistika", str. 331., Školska knjiga, Zagreb, 2004. godina

¹³ Šošić I.; "Primijenjena statistika", str. 237., Školska knjiga, Zagreb, 2004. godina

¹⁴ http://www.ehow.com/info_8587954_differences-between-parametric-nonparametric-tests.html#page=0; 3. travnja 2013. godine

¹⁵ <http://polj.uns.ac.rs/Files/STATISTIKA/STATISTICKE%20METODE%20TEHNIKA-UREDJENJE%20VODA/140%20NEPARAMETARSKA%20STATISTIKA.pdf>; 24. lipanj 2013. godine

prikladni su i za testiranje hipoteza na temelju uzoraka iz osnovnog skupa koju čine modaliteti kvalitativnih (numeričkih) varijabli.¹⁶ Neparametarske testove karakterizira jednostavnost uporabe. Manja statistička snaga predstavlja glavnu manu neparametarskih testova u odnosu na parametarske testove pa ako je upotreba parametarskog t-testa dopuštena, tada se uvijek preferira njegova upotreba nego upotreba njegovog neparametarskog ekvivalenta iz razloga jer se koristi ista razina značajnosti za oba testa pa je snaga neparametarskog testa uvijek manja od parametarskog ekvivalenta. Jedna od prednosti neparametarskih testova je mogućnost provođenja testa na skupovima različitih oblika što nije slučaj kod parametarskih testova.¹⁷ Dakle, neparametarski testovi koriste se najčešće u sljedećim slučajevima:

- nepoznata sampling-distribucija
- ne postavljaju se pretpostavke o obliku distribucije, točnije podaci nisu normalno distribuirani
- koriste se kvalitativni podaci ili su podaci mjereni na nominalnoj ili ordinalnoj skali (iako se neparametarski testovi mogu koristiti i nad podacima mjenim na intervalnoj i omjernoj skali)

Neparametarski testovi se odnose na jedan skup, dva ili više osnovnih skupova, a polaze od jednog, dva ili više nezavisnih ili zavisnih uzoraka.¹⁸

Katkada distribucija osnovnog skupa nije poznata ili nije, na primjer, u obliku normalne distribucije, a mali broj podataka dopušta uporabu određenih postupaka testiranja. Podaci koji čine uzorak kadšto su kvalitativni, mjereni na nominalnoj ili ordinalnoj skali, pa se u tom slučaju ne mogu primijeniti predočeni postupci testiranja. Testiranja hipoteza koje ne počivaju na potpunoj specifikaciji distribucije osnovnog skupa u sklopu su neparametarske statistike.¹⁹

Neki od često korištenih neparametarskih testova su: Wilcoxonov test, Mann-Whitney-Wilcoxonov test, hi-kvadrat test, Kruskal-Wallisov test, itd.

¹⁶ Šošić I.; "Primijenjena statistika", str. 331., Školska knjiga, Zagreb, 2004. godina

¹⁷ <http://polj.uns.ac.rs/Files/STATISTIKA/STATISTICKE%20METODE%20TEHNIKA-UREDJENJE%20VODA/140%20NEPARAMETARSKA%20STATISTIKA.pdf>; 24. lipanj 2013. godine

¹⁸ Šošić I.; "Primijenjena statistika", str. 331., Školska knjiga, Zagreb, 2004. godina

¹⁹ Šošić I.; "Primijenjena statistika", str. 331., Školska knjiga, Zagreb, 2004. godina

2.8. Usporedba parametarskih i neparametarskih testova

Znatan dio statističkih testova zahtijeva normalnu raspodjelu rezultata u populaciji. U praksi, često se nailazi na situacije kad nije poznata distribucija populacije ili čak se zna da populacija nije normalna. Čest je slučaj u nekim društvenim znanostima (npr. sociologiji) da se neke pojave distribuiraju upravo "suprotno" od normalne raspodjele. Na primjer, to je slučaj sa stavovima koji često daju tzv. "*U*-raspodjelu", tj. najveće frekvencije nalaze se na ekstremnim vrijednostima apscise. Jednako tako se ne može veći broj statističkih testova primijeniti ako rezultati nisu izraženi mjernim jedinicama nego kvalitativnim kategorijama ("zdrav", "bolestan", "mlad", "star", itd.). Parametarski testovi se služe mjernim podacima koji se normalno distribuiraju i upotrebljavaju se kod podataka izraženih intervalnom i omjernom skalom dok kod neparametarskih testova nije važno je li populacija normalno distribuirana i koriste se kvalitativni podaci koji se mjere nominalnom i ordinalnom skalom. Neparametarske testove *dopušteno* je i moguće primijeniti i pri obradi podataka koji su izraženi intervalnim i omjernim skalama, ali bi takav postupak bio neracionalan jer na taj način se namjerno gubi niz informacija i precizniji postupak se zamjenjuje aproksimativnim postupkom. Statističari kažu da je snaga neparametarskih testova manja od snage parametarskih testova. Ako između dvije populacije postoji razlika, to će se obično preciznije i uspješnije ustanoviti pomoću parametarskih nego neparametarskih testova.²⁰

2.9. Wilcoxonov test (Wilcoxon one sample signed rank test)

Wilcoxonov test na osnovi ekvivalentnih parova se primjenjuje pri testiranju hipoteze o jednakosti medijana dvaju simetrično raspoređenih osnovnih skupova.²¹

Karakteristike Wilcoxonovog test na osnovi ekvivalentnih parova su:

- Temelj testa je slučajni uzorak n parova vrijednosti kvantitativne varijable. Dva zavisna slučajna uzorka su podloga testa. Koristi se ako se uzorci dvaju populacija pojavljuju zajedno jer nisu neovisni jedan o drugome.
- Vrijednosti u paru odnose se na mjerenja provedena na *istoj* statističkoj (eksperimentalnoj) jedinici ili se odnose na dvije različite jedinice koje su svrstane u

²⁰ Petz, B.; Kolesarić, V.; Ivanec, D.; "Petzova statistika – Osnovne statističke metode za nematematičare"; str. 321., "Naklada Slap", studeni 2012. godina

²¹ Šošić I.; "Primijenjena statistika", str. 340., Školska knjiga, Zagreb, 2004. godina

par prema jednom kriteriju ili više kriterija definiranih planom istraživanja (eksperimenta).²²

- Podaci se mjere pomoću intervalne ili omjerne skale koja ne mora biti normalno distribuirana (ordinalna skala nije dovoljna jer se koriste razlike vrijednosti).²³
- Wilcoxonov test na osnovi ekvivalentnih parova je alternativa Studentovom t -testu za zavisne uzorke kada se distribucija ne može pretpostaviti normalnom raspodjelom.²⁴

To je test predznaka koji se odnosi na hipoteze o pretpostavljenoj vrijednosti medijana uzima u obzir samo predznak razlika vrijednosti i obilježja i medijana, a ne njihovu veličinu. Wilcoxonov test također počiva na predznacima spomenutih razlika. Osim toga, postupak testiranja uključuje i rangirane apsolutne razlike vrijednosti varijable i pretpostavljene vrijednosti medijana.

Rangiranje se provodi pridruživanjem prvih n prirodnih brojeva apsolutnim razlikama. Najmanjoj apsolutnoj vrijednosti razlike pridružuje se broj jedan, sljedećoj dva, i tako dalje redom sve do najveće vrijednosti razlike s pridruženim brojem n . Postoje li dvije ili više jednakih apsolutnih vrijednosti razlika, svakoj od njih pridružit će se jedan prosječan rang. Wilcoxonov test polazi od istih hipoteza kao i test predznaka. Kritične vrijednosti sampling-distribucije određene nultom hipotezom tabelirane su, pa se odluka donosi usporedbom test-veličine i kritičnih (teorijskih) vrijednosti.

Wilcoxonov test o pretpostavljenoj vrijednosti počiva na uzorku vrijednosti veličine n koji čine vrijednosti numeričke ili rang-varijable i koji potječe iz osnovnog skupa simetrično raspoređenog prema nepoznatom medijanu. Ako se sa η_0 označi pretpostavljena vrijednost medijana, koraci, odnosno postupci pri provođenju testa su sljedeći:

- Utvrđivanje razlika vrijednosti obilježja i pretpostavljene vrijednosti medijan ($x_i - \eta_0$).
- Isključivanje iz daljnjeg postupka svakog podatka kojemu je razlika ($x_i - \eta_0$) jednaka nuli te smanjivanje veličine uzorka za broj razlika jednakih nuli.
- Rangiranje apsolutne vrijednosti razlika $|x_i - \eta_0|$ tako da se najmanjoj razlici pridružuje broj jedan, sljedećoj po veličini dva, a najvećoj n . Ima li više jednakih apsolutnih razlika, svakoj se pridruži prosječan rang (aritmetička sredina) pripadajućih rangova.

²² Ibid; str. 340.

²³ http://en.wikipedia.org/wiki/Wilcoxon_signed-rank_test; 1. lipanj 2013. godine

²⁴ http://en.wikipedia.org/wiki/Wilcoxon_signed-rank_test; 1. lipanj 2013. godine

- Pridruživanje svakom rangu predznaka, i to predznaka + ako je pripadajuća razlika $(x_i - \eta_0) > 0$, a predznaka – ako je pripadajuća razlika $(x_i - \eta_0) < 0$.
- Određivanje test-veličine. Test-veličina je zbroj rangova s pozitivnim predznakom T_+ ili zbroj rangova s negativnim predznakom T_- . ukupan zbroj rangova s pozitivnim i s negativnim predznakom jednak je $\frac{1}{2} n (n+1)$.
- Način donošenja odluke o ishodu testa ovisi o tome je li test dvosmjernan ili jednosmjernan. Uspoređuje se test-veličina s teorijskom vrijednosti sampling-distribucije.

Hipoteze su:

1) $H_0 \dots \eta = \eta_0$ $H_1 \dots \eta \neq \eta_0$	2) $H_0 \dots \eta \leq \eta_0$ $H_1 \dots \eta > \eta_0$	3) $H_0 \dots \eta \geq \eta_0$ $H_1 \dots \eta < \eta_0$
--	--	--

Hipoteze (1) se odnose na dvosmjernan test. Test-veličina je $\min \{T_+, T_-\}$. Test (2) je jednosmjernan (na desnu stranu), a test-veličina je T_- . Test (3) je jednosmjernan (na lijevu stranu). Test veličina ovdje je T_+ .

Nulta se hipoteza ne prihvaća ako je test-veličina jednaka teorijskoj (kritičnoj) vrijednosti ili je manja od nje. U protivnome, prihvaća se nulta hipoteza. Teorijske vrijednosti tabelirane su za različite razine signifikantnosti i $n \leq 25$. Kad je $n > 25$, rabi se z-test. Test- veličina empirijski je z-omjer:

$$Z = \frac{T - \mu_T}{\sigma_T}, \quad \mu_T = \frac{1}{4} n(n+1), \quad \sigma_T = \sqrt{\frac{1}{24} n (n + 1)(2n + 1)}.$$

Odluka se donosi usporedbom empirijskog omjera s teorijskom vrijednosti za z jedinične normalne distribucije koja ovisi o obliku hipoteza i o razini signifikantnosti α . Pri provođenju testa pretpostavlja se da je broj izostavljenih vrijednosti uzorka i broj jednakih vrijednosti razlika malen u odnosu prema ukupnom broju članova uzorka. U protivnome, treba primijeniti modificirani izraz za računanje test-veličine.

2.10. Koeficijent korelacije ranga Spearmana

Koeficijentom korelacije ranga Spearmana mjeri se stupanj i smjer povezanosti dviju pojava predloženih parovima rang-varijabli. Ako su varijable numeričke, valja ih transformirati u varijable ranga. Značajnost korelacije ranga testira se pomoću sampling-distribucije, koja ne ovisi o obliku distribucije osnovnog skupa, pa se takav test ubraja među neparametarske testove.

Podatke ordinalne varijable moguće je poredati po ordinalnom intezitetu svojstava te se promatraju jedino razlike u rangu, a ne originalne razlike u pojedinim vrijednostima. Temelj su Spearmanova koeficijenta korelacije ranga parovi modaliteta rang-varijabli ili numeričkih varijabli transformiranih u rang-varijable. Modaliteti su svake rang-varijable iz skupa n prirodnih brojeva.

Parovi su:

$$r(x_i), r(y_i), i=1,2,\dots,n.$$

Koeficijent linearne korelacije (Pearsonova forma) računan uporabom parova modaliteta rang-varijabli naziva se Spearmanovim koeficijentom korelacije ranga.

Koeficijent je dan izrazom:

$$R_s = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n^3 - n}, \quad d_i = r(x_i) - r(y_i), \quad -1 \leq r_s \leq 1.$$

Ako su u svakom paru rangovi jednaki, njihove su razlike jednake nuli, a koeficijent poprima vrijednost 1. U tome slučaju govorimo o potpunoj (perfektnoj) pozitivnoj korelaciji ranga. Kada je redoslijed modaliteta jedne rang-varijable obrnut od redoslijeda druge varijable u paru, koeficijent će poprimiti vrijednost -1, pa je korelacija ranga potpuna i negativnog smjera. Za najveće neslaganje rangova drugim član s desne strane navedenog izraza jest 1, a koeficijent korelacije ranga jednak je nuli. Pri računanju koeficijenata korelacije pretpostavlja se da nema vezanih rangova, ili da je njihov broj zanemariv prema broju parova.

Kada podaci za utvrđivanje korelacije ranga tvore uzorak, koeficijent korelacije ranga r_s jest test veličina u testu hipoteze o koeficijentu korelacije ranga osnovnog skupa. Testovi mogu

biti dvosmjerni ili jednosmjerni. Ako je razina signifikantnosti α , odluka se donosi na usporedbom test-veličine r_s (koeficijent korelacije ranga uzorka) s kritičnom vrijednosti sampling-distribucije koeficijentata korelacije ranga za vjerojatnost $\frac{\alpha}{2}$ odnosno α i veličinu uzorka n . Vrijednosti su sampling distribucije tabelirane. Hipoteze i područja prihvatanja i neprihvatanja nulte hipoteze dani su u tablici:

Tablica 3: Hipoteze i područja prihvatanja i neprihvatanja nulte hipoteze:

Vrsta testa	Nulta hipoteza	Alternativna hipoteza	Područje prihvatanja nulte hipoteze	Područje odbacivanja nulte hipoteze
Dvosmjernan	$H_0 \dots \rho_s = 0$	$H_0 \dots \rho_s \neq 0$	$r_{s,\alpha/2} < r_s < r_{s,\alpha/2}$	$r_s < -r_{s,\frac{\alpha}{2}} \text{ ili } r_s > r_{s,\alpha/2}$
Jednosmjernan (o pozitivnoj korelaciji ranga)	$H_0 \dots \rho_s \leq 0$	$H_0 \dots \rho_s > 0$	$r_s < r_{s,\alpha}$	$r_s > r_{s,\alpha}$
Jednosmjernan (o negativnoj korelaciji ranga)	$H_0 \dots \rho_s \geq 0$	$H_0 \dots \rho_s < 0$	$r_s > -r_{s,\alpha}$	$r_s < -r_{s,\alpha}$

Izvor: Šošić I., "Primijenjena statistika", str. 424., Školska knjiga, Zagreb, 2004. Godina

U nultoj hipotezi dvosmjernog testa sadržana je tvrdnja da je koeficijent korelacije ranga osnovnog skupa jednak nuli. Alternativna hipoteza sadrži suprotnu tvrdnju, tj. tvrdnju da postoji tendencija da su velike vrijednosti jedne varijable u paru s velikim vrijednostima druge varijable (pozitivna korelacija ranga), ili da su velike vrijednosti jedne varijable u paru s malim vrijednostima druge varijable (negativna korelacija ranga). Na analogan se način tumači sadržaj hipoteza u jednosmjernim testovima.

2.11. Hi kvadrat test

Hi kvadrat test (χ^2 -test) primjenjuje se u različitim statističkim postupcima. Na primjer, taj se test rabi da bi se ispitala pretpostavka o obliku distribucije populacije iz koje potječe uzorak. Pri tome se testira hipoteza o distribuciji populacije s pretpostavljenim parametrima. Test veličina temelji se na empirijskom hi-kvadratu koji ovisi o razlikama među očekivanim frekvencijama prema modelu navedenom u nultoj hipotezi i empirijskim frekvencijama

distribucije.²⁵ χ^2 testom ispituje se, primjerice, hipoteza o jednakosti proporcija triju ili više osnovnih skupova, odnosno triju ili više stratumata jednog osnovnog skupa.

Provedba χ^2 -testa o obliku distribucije populacije počiva na slučajnom uzorku n članova koji predložuje oblike kvalitativne ili kvantitativne varijable. Postupku testiranja prethodi razvrstavanje n podataka iz uzorka prema načelu iscrpnosti i isključivosti u k grupa, čime se dolazi do empirijske distribucije, odnosno statističkog niza. Slijedi izbor modela - teorijske distribucije s kojom se uspoređuje empirijska distribucija. Ako parametri teorijske distribucije nisu poznati, procjenjuju se uporabom podataka iz uzorka. Na temelju pretpostavljene distribucije osnovnog skupa računaju se očekivane frekvencije koje se uspoređuju s empirijskim frekvencijama.²⁶

Test polazi od ovih hipoteza:

H_0 ...distribucija osnovnog skupa je specificirana oblika

H_1 ... distribucija osnovnog skupa nije specificirana oblika

Test-veličina je empirijski χ^2 , koji je predložen sljedećim izrazom (Formula 1.):

$$\chi^2 = \frac{(f_1 - e_1)^2}{e_1} + \frac{(f_2 - e_2)^2}{e_2} + \dots + \frac{(f_i - e_i)^2}{e_i} + \dots + \frac{(f_k - e_k)^2}{e_k},$$

$$\chi^2 = \sum_{i=1}^k \frac{(f_i - e_i)^2}{e_i}.$$

U navedenom izrazu f_i su apsolutne frekvencije, a e_i su očekivane apsolutne frekvencije prema distribuciji navedenoj u nultoj hipotezi.

Uzme li se da je nulta hipoteza istinita, tada je moguće pokazati da je test-veličina izračunata pomoću podataka iz dovoljno velikog uzorka približno distribuirana prema χ^2 -distribuciji s $(k - g - 1)$ stupnjeva slobode, gdje je k broj grupa (članova statističkog niza), g je broj procijenjenih parametara distribucije osnovnog skupa ($g = 0$ ako su parametri pretpostavljene distribucije poznati).²⁷

Odluka se donosi usporedbom test veličine χ^2 s teorijskom vrijednosti $\chi^2_{\alpha}(k - g - 1)$, gdje je α odabrana razina signifikantnosti, a $(k - g - 1)$ broj stupnjeva slobode.

²⁵ Šošić I, *Primjenjena statistika*, Školska knjiga, Zagreb, 2006., 2. izmijenjeno izdanje, str. 352

²⁶ Šošić I, *Primjenjena statistika*, Školska knjiga, Zagreb, 2006., 2. izmijenjeno izdanje, str. 352

²⁷ Šošić I, *Primjenjena statistika*, Školska knjiga, Zagreb, 2006., 2. izmijenjeno izdanje, str. 353

$$P(X > \chi^2_{\alpha}(k - g - 1)) = \alpha, \text{ gdje je } X \sim \chi^2(k - g - 1)$$

Nulta se hipoteza prihvaća ako je empirijski hi-kvadrat jednak teorijskoj vrijednosti hi-kvadrat distribucije ili manji od nje, a ne prihvaća kada je empirijski hi-kvadrat veći od teorijske vrijednosti hi-kvadrat distribucije.²⁸

χ^2 -test može se prikazati u šest koraka:

U prvom koraku postavlja se hipoteza:

- Hipoteze u testu o obliku distribucije
 H_0 ... distribucija je određenog oblika
 H_1 ... distribucija nije određenog oblika

U koraku dva se odabire razina značajnosti

Najčešće razine značajnosti su i u hi kvadrat testovima: 0,1; 0,05 i 0,01.

U trećem koraku se odabere statistički test

Postoje tri vrste testiranja hipoteza (hi-kvadrat test o distribuciji, test neovisnosti i test homogenosti) za koje se primjenjuje statistički test χ^2 -test. Ovisno o postavljenom istraživačkom problemu odabire se χ^2 -test procedura.

U koraku četiri slijedi izračunavanje pogreške testiranja

Uz odabranu razinu značajnosti i vrstu hi kvadrat testa određuje se područje (ne) odbacivanja nul hipoteze. Područje (ne)odbacivanja nul-hipoteze određuje se utvrđivanjem teorijske vrijednosti hi-kvadrat testa. Teorijska vrijednost hi-kvadrat testa (χ^2_{α}) utvrđuje se uz pomoć tablice hi-kvadrat distribucije.


U koraku pet se izračunavaju testne veličine

Testna veličina hi-kvadrat testa naziva se hi-kvadrat test pokazatelj (χ^2) te se uspoređivanjem njegove vrijednosti s teorijskom vrijednosti hi kvadrat testa (χ^2_{α}) donosi odluka o (ne)odbacivanju postavljene nul hipoteze. Vrijednosti testne statistike mogu se očitati iz tablica hi-kvadrat distribucije kako je prikazano u tablici 4.

²⁸ Šošić I, *Primjenjena statistika*, Školska knjiga, Zagreb, 2006., 2. izmijenjeno izdanje, str. 353

U koraku šest se donosi odluka o nul-hipotezi. Nul-hipotezu moguće je odbaciti ili, bez dovoljno dokaza za njezino odbacivanje, ne odbaciti. Hi- kvadrat test provodi se na varijablama koje su mjerene na bilo kojoj mjernoj ljestvici te predstavlja jedan od najčešće korištenih neparametrijskih statističkih testova. Njegova prednost mogućnost je testiranja podataka mjerenih nominalnom i ordinalnom razinom mjerenja te ne zahtijeva zadovoljavanje pretpostavke o određenom obliku distribucije populacije.²⁹

Slika 1. χ^2 -distribucije za stupnjeve slobode, $k = 1, 2, 3, 4, 6, 9$




Izvor: <http://andee.blog.siol.net/2012/02/12/kratka-interaktivna-delavnica-ekonometrije-preverjanje-hipotez-in-statisticne-porazdelitve/>

U tablici 2. prikazane su granične vrijednosti hi-kvadrat distribucije za različite stupnjeve slobode. Za zadani stupanj slobode i površinu desnog kraka u tablici je dan pripadni kvantil. Tako je, na primjer, za slučajnu varijablu X koja se ravna prema hi-kvadrat distribuciji s 5 stupnjeva slobode, odnosno $X \sim \chi^2(5)$, $P(X > 0.554) = P(X \geq 0.554) = 0.99$ i $P(X > 9.236) = P(X \geq 9.236) = 0.1$. Također, u prethodnim primjerima može se zapisati $\chi^2_{0.99}(5) = 0.554$ i $\chi^2_{0.1}(5) = 9.23$.

²⁹ Horvat J.; Mijoč J.; "Osnove statistike", str. 382., Ljevak, Zagreb, svibanj 2012. Godine str. 432.

Slika 2. Granične vrijednosti varijable χ^2 za pripadne površine ispod krivulje i k stupnjeva slobode



k	0,99	0,98	0,95	0,90	0,80	0,50	0,20	0,10	0,05	0,02	0,01	0,001
1	0,000	0,001	0,004	0,016	0,064	0,455	1,642	2,706	3,841	5,412	6,635	10,828
2	0,020	0,040	0,103	0,211	0,446	1,386	3,219	4,605	5,991	7,824	9,210	13,816
3	0,115	0,185	0,352	0,584	1,005	2,366	4,642	6,251	7,815	9,837	11,345	16,266
4	0,297	0,429	0,711	1,064	1,649	3,357	5,989	7,779	9,488	11,668	13,277	18,467
5	0,554	0,752	1,145	1,610	2,343	4,351	7,289	9,236	11,070	13,388	15,086	20,515
6	0,872	1,134	1,635	2,204	3,070	5,348	8,558	10,645	12,592	15,033	16,812	22,458
7	1,239	1,564	2,167	2,833	3,822	6,346	9,803	12,017	14,067	16,622	18,475	24,322
8	1,646	2,032	2,733	3,490	4,594	7,344	11,030	13,362	15,507	18,168	20,090	26,124
9	2,088	2,532	3,325	4,168	5,380	8,343	12,242	14,684	16,919	19,679	21,666	27,877
10	2,558	3,059	3,940	4,865	6,179	9,342	13,442	15,987	18,307	21,161	23,209	29,588
11	3,053	3,609	4,575	5,578	6,989	10,341	14,631	17,275	19,675	22,618	24,725	31,264
12	3,571	4,178	5,226	6,304	7,807	11,340	15,812	18,549	21,026	24,054	26,217	32,909
13	4,107	4,765	5,892	7,042	8,634	12,340	16,985	19,812	22,362	25,472	27,688	34,528
14	4,660	5,368	6,571	7,790	9,467	13,339	18,151	21,064	23,685	26,873	29,141	36,123
15	5,229	5,985	7,261	8,547	10,307	14,339	19,311	22,307	24,996	28,259	30,578	37,697
16	5,812	6,614	7,962	9,312	11,152	15,338	20,465	23,542	26,296	29,633	32,000	39,252
17	6,408	7,255	8,672	10,085	12,002	16,338	21,615	24,769	27,587	30,995	33,409	40,790
18	7,015	7,906	9,390	10,865	12,857	17,338	22,760	25,989	28,869	32,346	34,805	42,312
19	7,633	8,567	10,117	11,651	13,716	18,338	23,900	27,204	30,144	33,687	36,191	43,820
20	8,260	9,237	10,851	12,443	14,578	19,337	25,038	28,412	31,410	35,020	37,566	45,315
21	8,897	9,915	11,591	13,240	15,445	20,337	26,171	29,615	32,671	36,343	38,932	46,797
22	9,542	10,600	12,338	14,041	16,314	21,337	27,301	30,813	33,924	37,659	40,289	48,268
23	10,196	11,293	13,091	14,848	17,187	22,337	28,429	32,007	35,172	38,968	41,638	49,728
24	10,856	11,992	13,848	15,659	18,062	23,337	29,553	33,196	36,415	40,270	42,980	51,179
25	11,524	12,697	14,611	16,473	18,940	24,337	30,675	34,382	37,652	41,566	44,314	52,620
26	12,198	13,409	15,379	17,292	19,820	25,336	31,795	35,563	38,885	42,856	45,642	54,052
27	12,879	14,125	16,151	18,114	20,703	26,336	32,912	36,741	40,113	44,140	46,963	55,476
28	13,565	14,847	16,928	18,939	21,588	27,336	34,027	37,916	41,337	45,419	48,278	56,892
29	14,256	15,574	17,708	19,768	22,475	28,336	35,139	39,087	42,557	46,693	49,588	58,301
30	14,953	16,306	18,493	20,599	23,364	29,336	36,250	40,256	43,773	47,962	50,892	59,703
35	18,509	20,027	22,465	24,797	27,836	34,336	41,778	46,059	49,802	54,244	57,342	66,619
40	22,164	23,838	26,509	29,051	32,345	39,335	47,269	51,805	55,758	60,436	63,691	73,402
45	25,901	27,720	30,612	33,350	36,884	44,335	52,729	57,505	61,656	66,555	69,957	80,077
50	29,707	31,664	34,764	37,689	41,449	49,335	58,164	63,167	67,505	72,613	76,154	86,661
60	37,485	39,699	43,188	46,459	50,641	59,335	68,972	74,397	79,082	84,580	88,379	99,607
70	45,442	47,893	51,739	55,329	59,898	69,334	79,715	85,527	90,531	96,388	100,425	112,317
80	53,540	56,213	60,391	64,278	69,207	79,334	90,405	96,578	101,879	108,069	112,329	124,839
90	61,754	64,635	69,126	73,291	78,558	89,334	101,054	107,565	113,145	119,648	124,116	137,208
100	70,065	73,142	77,929	82,358	87,945	99,334	111,667	118,498	124,342	131,142	135,807	149,449
500	429,388	437,219	449,147	459,926	473,210	499,334	526,401	540,930	553,127	567,070	576,493	603,446

Izvor: https://www.google.hr/url?sa=t&rct=j&q=&esrc=s&source=web&cd=1&ved=0CC4QFjAA&url=http%3A%2F%2Fwww.sumfak.unizg.hr%2Fdownload.aspx%3Ffile%3D%2Fupload%2Fsec_001%2Fins_002%2FBiometrika%2FTablica%2520hikvadrat%2520distribucije.pdf&ei=RPJFUbPmAcIMtQbbj4FQ&usg=AFQjCNHn7JfxcMqkQ-ZrdLwD2EFcCkVYA&sig2=qLuOAKTqtFnNp8HQNHKQ1A&bvm=bv.43828540,d.Yms

3. Automobilska industrija i utjecaj ekonomske krize

Automobilska industrija jedna je od najvećih i najvažnijih industrija u svijetu, a automobilske se kompanije ubrajaju među najsnažnije i najveće svjetske kompanije. Niti jedan drugi industrijski proizvod, osim možda računala, nije toliko revolucionarno i dramatično promijenio čovjekovo poimanje vremena i prostora koliko je to bio automobil. Nafta je kao prirodna i geološka pojava predstavlja a nužni preduvjet za nastanak i razvoj ovog industrijskog proizvoda koji je značajno utjecao na transformaciju ljudskog društva i geografskog prostora.³⁰ Posljednjih sto godina bilo je stoljeće motorizacije, s globalnom proizvodnjom koja je 2011. godine prešla 80 milijuna vozila³¹ te s postotkom vlasništva vozila osoba koje posjeduju vozačku dozvolu od 90% u Sjedinjenim Američkim državama (SAD) i oko 50 do 60% u zapadnoj Europi i Japanu³². Autoindustrija je sa svim povezanim industrijama najveći proizvođački sektor na svijetu i zauzima oko 15% ukupnog svjetskog bruto domaćeg proizvoda³³. Prema svojoj veličini, autoindustrija je jedan od najvećih svjetskih poslodavaca pa je izravno ili neizravno odgovorna za svaki deveti posao u razvijenim zemljama³⁴.

U prošlosti, operacije proizvodnje dijelova automobila bile su integralni dio velikog postrojenja za proizvodnju automobila.³⁵

S obzirom na činjenicu da automobili spadaju u grupu trajnijih dobara, vozači bi, osim samoga troška nabave automobila, posebnu pozornost trebali posvetiti i operativnom trošku upotrebe automobila. U takve troškove spadaju troškovi uvoza, registracije automobila, trošak osiguranja, održavanja i trošak goriva. Najveći i najvažniji trošak upotrebe automobila je trošak goriva koji uvelike ovisi o veličini, težini, obliku i snazi automobila. Ukoliko se posjeduju veća, teža i snažnija osobna vozila, pretpostavlja se da će biti i veća potrošnja goriva.

³⁰ Vlatka Bilas, Sanja Franc, Branimir Arbanas, Utjecaj aktualne ekonomske krize nastajanje i perspektive razvoja autoindustrije, Ekonomski fakultet Sveučilišta u Zagrebu, 2013.

³¹ <http://oica.net/wp-content/uploads/industry-key-figures-oica-pressrelease>.

³² http://www.unido.org/fileadmin/user_media/Publications/RSF_DPR/WP162009_Ebook.pdf

³³ http://www.global-labouruniversity.org/fileadmin/master_theses/South_Africa/Thesis_Mashilo.pdf

³⁴ http://www.unido.org/fileadmin/media/documents/pdf/Services_Modules/Automotive_Industry.pdf

³⁵ Haugh, D., Mourougana, A. i Chatal, O., 2010. The Automobile Industry in and Beyond the Crisis, *OECD Economics Department Working Papers, No. 745* [pdf] dostupno na: <http://dx.doi.org/10.1787/5kmmp8wg6cmq-en>

Prema tome, uslijed porasta cijene naftnih derivata očekuje se da će za mnoge vozače veći i snažniji automobili postati manje poželjni, pa će se u skladu s time i dogoditi promjene u potražnji za pojedinim automobilima na tržištu. Provedena znanstvena i stručna istraživanja pokazuju da je odabir automobila ovisi o cijena automobila, odlikama kupca (dohodak, obiteljski status, starosna dob), te svojstvima automobila (potrošnja, snaga). Također utjecaj cijene goriva na potražnju za automobilima nudi različite oblike prilagodbe u potražnji za automobilima i načinu njihove vožnje. Stalni porast cijena goriva dovodi do toga da kućanstva kratkoročno smanjuju učestalost i duljinu putovanja, a zatim u dugom roku zamjenjuju svoje vozilo efikasnijim automobilom. Cijene goriva također potiču kućanstva na promjenu lokacije rada i stanovanja. Kupci su prilikom odabira određenih proizvoda manje fokusirani na popratne troškove rada određenog proizvoda, nego na njegovu kupovnu cijenu. U tom kontekstu može se reći da kupci određenih automobila uglavnom vode računa prvenstveno o prodajnoj cijeni automobila, a sekundarno o budućim troškovima korištenja tog automobila.

Tržište automobila je raslo do 2008. godine, nakon čega u 2009. dolazi do značajnog pada³⁶. Mijenja se i udio automobila na benzin, kako u ukupnoj strukturi, tako i o pojedinim klasama vozila. Na tržištu se događaju dvije važne promjene koje idu u dva suprotna smjera. Padaju troškovi za kupnju automobila te rastu troškovi za goriva i maziva. Istovremeno rastu i troškovi popravaka.

Kako se povećavala nezaposlenost, ljudi su postajali sve nesigurniji za vlastiti posao i odustajali su od kupnje automobila. visoka cijena novog vozila i sve duži vijek trajanja potaknuo je kupce na odgodu kupnje novog vozila. Također, nedostupnost kredita onemogućila je mnogima od kupnju novog vozila. Programi kao što su zamjena vozila "staro za novo", koji subvencioniraju kupnju novog automobila uvelike privlače kupce na kupnju novog automobila.

Automobil od svojih prvih kilometara, osim pukog prijevoza, ima i zadaću prezentacije svoga vlasnika, njegova ukusa, statusa, u društvu, i uspjeha općenito, a što je društvo na nižoj civilizacijskoj razini, statusna je uloga automobila izraženija.³⁷


³⁶ Kovačević Zoran, Ivan Šušnjar, Gelo Tomislav, : Utjecaj kretanja cijena naftnih derivata na tržište automobila u Republici Hrvatskoj, Ekonomski fakultet Zagreb, 2014.

³⁷ Antončić Robert, Automobil vlada svijetom, Tisak Varteks, Varaždin, 2002. Str. 13.

3.1. Trendovi razvoja autoindustrije u svijetu

Autoindustrija je ključna komponenta ekonomskog rasta zbog brojnih poveznica unutar industrije, kao i same autoindustrije s ostatkom ekonomije. Autoindustrija jedna je od najvažnijih industrija i prema *Center for Automotive Research* (2010a), autoindustrija samo u SAD-u pridonosi oko 3,5% bruto domaćem proizvodu i izravno zapošljava preko 1,7 milijuna ljudi uključenih u dizajn, razvoj, proizvodnju te prodaju i servisiranje vozila.³⁸

Grafikon 1. Ukupan broj proizvedenih automobila u razdoblju od 2000. godine do 2011. Godine



Izvor: Vlatka Bilas, Sanja Franc, Branimir Arbanas: *Utjecaj aktualne ekonomske krize na stanje i perspektive razvoja autoindustrije* str. 301, Zagreb, 2013.

Proizvođači automobila morali su prilagoditi svoju proizvodnju jer su gotovo sve zemlje koje proizvode automobile bilježile oštar pad proizvodnje u 2008. godini, a posebno je velik pad zabilježen u zemljama kao što su Francuska, Španjolska i Italija.³⁹ U SAD-u, pad prodaje


³⁸ Vlatka Bilas, Sanja Franc, Branimir Arbanas: *Utjecaj aktualne ekonomske krize na stanje i perspektive razvoja autoindustrije*, Zagreb, 2013.

³⁹ Sturgeon, T. J. i Biesebroeck, J. V., 2010. Effects of the crisis on the automotive industry in developing countries, *Policy research working paper 5330, The World Bank* [pdf] dostupno na: [http://unstats.un.org/unsd/trade/s_geneva2011/refdocs/RDs/Automotive%20Industry%20and%20Crisis%20\(Sturgeon%20-%20Jun%202010\).pdf](http://unstats.un.org/unsd/trade/s_geneva2011/refdocs/RDs/Automotive%20Industry%20and%20Crisis%20(Sturgeon%20-%20Jun%202010).pdf)

trajnih dobara te ulaganja poduzeća u kupnju automobila pridonijelo je 20 do 30% padu BDP-a u drugoj polovici 2008. godine⁴⁰

Posljednjih godina proizvodnja automobila se polako premješta izvan OECD područja, većinom u BRIC zemlje (Brazil, Rusija, Indija, Kina) te ostale brzo rastuće ekonomije. Između 2000. i 2007. godine, udio SAD-a i Japana u ukupnoj svjetskoj proizvodnji automobila pao je s 40 na 30%, dok se udio zemalja izvan OECD-a povećao s razine proizvodnje od jednog automobila prema deset na razinu od jednog automobila prema pet automobila u odnosu prema razvijenim zemljama.⁴¹ Na grafikonu 2 prikazani su najveći svjetski proizvođači automobila u 2011. godini.

Grafikon 2. Najveći svjetski proizvođači automobila 2011. godine



Izvor: Vlatka Bilas, Sanja Franc, Branimir Arbanas: *Utjecaj aktualne ekonomske krize na stanje i perspektive razvoja autoindustrije* str. 303, Zagreb, 2013.

⁴⁰ Haugh, D., Mourougana, A. i Chatal, O., 2010. The Automobile Industry in and Beyond the Crisis, *OECD Economics Department Working Papers, No. 745* [pdf] dostupno na: <http://dx.doi.org/10.1787/5kmmp8wg6cmq-en>

⁴¹ Haugh, D., Mourougana, A. i Chatal, O., 2010. The Automobile Industry in and Beyond the Crisis, *OECD Economics Department Working Papers, No. 745* [pdf] dostupno na: <http://dx.doi.org/10.1787/5kmmp8wg6cmq-en>

SAD kao dugogodišnji najveći svjetski proizvođač automobila (do 2005. godine kada pada na drugo mjesto iza Kine), ima udio autoindustrije u proizvodnoj djelatnosti od oko 5,8%, dok primjerice Češka koja proizvodi nešto više od milijun automobila godišnje ima udio autoindustrije u proizvodnoj djelatnosti od 13%. Zanimljivo je da je Japan kao treći najveći svjetski proizvođač automobila ima sličan udio u proizvodnoj djelatnosti kao i Češka⁴²

3.2.Autoindustrija u Republici Hrvatskoj

Razvoj hrvatske automobilske industrije temelji se na dugoj tradiciji u srodnim sektorima, poput metalne proizvodnje, zavarivanja, proizvodnje plastike te inženjeringu. Hrvatske tvrtke koje se bave proizvodnjom automobilskih dijelova imaju tradiciju u visoko preciznoj proizvodnji s nultom stopom tolerancije na kvarove, a glavna konkurentska prednost je izvrsna kvaliteta njihovih proizvoda. Preko tri četvrtine dodane vrijednosti u automobilskoj industriji ostvaruje se upravo u proizvodnji dijelova za ugradnju te djelatnostima vezanim uz razvoj vozila i prateće djelatnosti. Na hrvatskom tržištu prisutne su i kompanije koje su se uspješno integrirale u sustav dobavljača rezervnih dijelova za vrhunske svjetske proizvođače automobila (PSA, GM, Fiat, BMW, Audi, Ford, Renault, Toyota, Volvo, i sl.).

Hrvatska se može pohvaliti i proizvodnjom električnih automobila XD (DOK-ING te Concept One – Rimac Automobili). Prednosti ulaska autoindustrije u Republiku Hrvatsku su, uz kvalitetno obrazovanu radnu snagu, izvrsna infrastruktura te blizina tržišta i pogona za proizvodnju automobila zemalja Zapadne i Srednje Europe.

Neki osnovne karakteristike hrvatske autoindustrije su:

- Hrvatska autoindustrija zapošljava 2,103 ljudi
- Procijenjeno je da je dodatnih 7,000 ljudi zaposleno u pratećim industrijama
- Prosječna bruto plaća isplaćena u automobilskoj industriji je 1,011€ (2012.)
- Udio automobilske industrije u ukupnom izvozu je 1,8%
- Oko 90% prihoda automobilske industrije generira izvozom⁴³


⁴² Haugh, D., Mourougana, A. i Chatal, O., 2010. The Automobile Industry in and Beyond the Crisis, *OECD Economics Department Working Papers, No. 745* [pdf] dostupno na:<http://dx.doi.org/10.1787/5kmmp8wg6cmq-en>

⁴³ <http://www.aik-invest.hr/sektori/automobilska-industrija/>

Autoindustrija zauzima tek mali udio u gospodarstvu Hrvatske. Prema podacima Agencije za investicije i konkurentnost (AIK) hrvatsku automobilsku industriju trenutno čini stotinjak proizvođača od kojih velika većina proizvodi dijelove ili pruža usluge više rangiranim proizvođačima u automobilskoj industriji. Organizacija autoindustrije je slaba i orijentirana samo na proizvodnju rezervnih dijelova. Kada se sagledaju činjenice može se primijetiti koliko je hrvatsko tržište zahvalno. Problem, međutim, predstavlja nedostatak transparentnosti i slabo zakonodavstvo. Hrvatsko pravosuđe, administracija, nezdrava porezna klima, te izostanak nacionalne strategije odbijaju sve investitore. Bez obzira na kvalitetnu visoko obrazovanu radnu snagu, solidnu infrastrukturu, te blizinu tržišta i pogona za proizvodnju automobila zemalja Zapadne u Srednje Europe, Hrvatska nije zabilježila gotovo ni jedno značajnije *greenfield* ulaganje u sektor proizvodnje automobila i automobilskih dijelova. U cijeloj priči je paradoksalna skupa radna snaga, a problem predstavlja i izostanak aktivne politike stranih ulaganja u toj industrijskoj grani.

Tržište automobila u Hrvatskoj, kako novih, tako i rabljenih, određeno je različitim varijablama među kojima se u znanstvenoj i stručnoj literaturi uobičajeno analizira i jedna mikroekonomska varijabla, cijena naftnih derivata. Svako će povećanje cijene naftnih derivata uzrokovati povećanje troška korištenja automobila. Veličina tog troška najviše će ovisiti o karakteristikama samih automobila odnosno o veličini, snazi i samoj potrošnji određenoga modela. Način na koji potrošači, odnosno vozači, reagiraju na porast cijene naftnih derivata je višestruk, a jačina reakcije prvenstveno ovisi o vremenu prilagodbe. U kratkom roku kada se cijena benzina neočekivano poveća, potrošač može burnije reagirati i napraviti supstituciju drugim gorivom ili prelaskom na drugi oblik vožnje. Odgovor vozača na povećanje cijena naftnih derivata kratkoročno se najčešće ogleda kroz smanjenje broja prijeđenih kilometara i kroz povećanje racionalnije vožnje (racionalna vožnja se ogleda kroz poboljšanje održavanja automobila ili u promjenama načina vožnje kao što je lakše ubrzavanje ili smanjenje ukupne brzine vožnje). Međutim, dugoročno ponašanje vozača može se prilagoditi višoj cijeni naftnih derivata. Mogu se kupiti manja i po potrošnji naftnih derivata učinkovitija vozila, voziti bicikl, putovati vlakom, autobusom, tramvajem ili preseliti bliže mjestu rada.

Grafikon 3: Broj novoregistriranih automobila u Republici Hrvatskoj




Izvor: Izrada autora

Na grafikonu 3 može se primijeti rast broja novoregistriranih automobila u Republici Hrvatskoj sve do 2008. godine, kada doseže vrhunac. Nakon toga, kao posljedica ekonomske krize, prodaja doživljava nagli pad. Izuzetak su nekoliko marki koje za cijelo vrijeme prodaje bilježe konstantu, ili čak pojedine i porast.

Došlo je do promjena u razini broja automobila, ali i promjena u strukturi. Tako je tržište raslo do 2008. godine, nakon čega dolazi do značajnog pada broja novoregistriranih automobila. Istovremeno se mijenjao i udio automobila na benzin. Na tržištu automobila događaju se dvije važne promjene koje idu u dva suprotna smjera.

Grafikon 4: Usporedba udjela novoregistriranih automobila s pogonom na benzin i automobila s pogonom na dizel



Izvor: Izračun autora (Podaci preuzeti s stranica Ministarstvo unutarnjih poslova, Energija u Hrvatsko 2005.-2007. i http://www.autonet.hr/adminmax/files/387_2014-gorivo.htm 2007.-2013.)

Na grafikonu 4 može se uočiti kako je do 2009. godine postupno rastao udio novoregistriranih automobila s pogonom na benzin, te nakon 2009. godine, taj udio postupno počinje opadati, te je 2013. godine došao na razinu ispod razine u 2008. godini. Prema analizi Kovačevića, Šušnjare i Gele veze cijena naftnih derivata i ukupne i strukturne promjene novoregistriranih osobnih automobila od 2005. do 2013. na području Republike Hrvatske dobiveni su rezultati koji ne upućuju na povezanost godišnjih kretanja cijena benzina i dizela s udjelom u strukturi novoregistriranih osobnih automobila (prema klasi motora). Također provedena analiza ne pokazuje postojanje veze između godišnjih kretanja cijena benzina i dizela i ukupno novoregistriranih automobila (prema klasi motora).⁴⁴

⁴⁴ Kovačević Zoran, Ivan Šušnjar, Gelo Tomislav, : Utjecaj kretanja cijena naftnih derivata na tržište automobila u Republici Hrvatskoj, Ekonomski fakultet Zagreb, 2014.

4.Rezultati

U radu se ispituje utjecaj gospodarske krize na tržište automobila u Hrvatskoj, odnosno ispitan je broj novoregistriranih automobila po markama prije i poslije prijelomne 2008./2009. godine. Također se ispituje kretanje prodaje automobila po markama s obzirom na pogonsko gorivo.

Podatci potrebni za izračun preuzeti su s internetske stranice <http://www.autonet.hr/rubrika/hr-trziste>. Preuzeti su podaci o broju novoregistriranih automobila u razdoblju 2005.-2013. s obzirom na marku automobila. Također, preuzeti su podaci o broju novoregistriranih automobila u razdoblju 2007-2013. s obzirom na pogonsko gorivo i marku.

Iz grafikona 3 vidljivo je kako se broj novoregistriranih automobila smanjio u razdoblju poslije 2008. godine u odnosu na razdoblje prije. Stoga ovdje neće biti prikazano provođenje formalnog statističkog testa. Ipak, potrebno je napomenuti kako je razlika u broju novoregistriranih automobila u razdoblju prije i poslije 2008. godine statistički značajna i gledajući rezultate po pojedinim markama. Naime testiranjem hipoteze o jednakosti prosječnog broja novoregistriranih automobila prije i poslije 2008. godine, dakle postavljanjem hipoteza:

H_0 : prosječan broj novoregistriranih automobila prije i poslije 2008. godine je jednak

H_1 : prosječan broj novoregistriranih automobila prije i poslije 2008. godine nije jednak

i provođenjem Wilcoxonovog testa na osnovi ekvivalentnih parova, dobivaju se rezultati koji ukazuju na odbacivanje nulte hipoteze ($z=5.28$, $p=0$). Dakle, gospodarska kriza je utjecala na smanjenje broja novoregistriranih automobila za većinu marki. Izuzetak su Kia i Chevrolet USA.

Tablica 4: Output microsoft excel


Wilcoxon Signed Rank Test	
variables:	prosjeak prije - prosjeak poslije
838	sum of positive ranks
23	sum of negative ranks
41	N
430,50	expected value
77,17	standard deviation
5,28	Z
1,29E-07	p-value (two-tailed)

Izvor: Izrada autora

4.1.Usporedba rangova automobilskih marki prije, poslije i za vrijeme trajanja krize

Dalje, ispitana je jednakost rangova četrdeset i dvije najprodavanije marke automobila u Hrvatskoj prije, poslije i za vrijeme trajanja krize prema broju novoregistriranih automobila. Cilj je ispitati jesu li kriza utjecala na preferencije potrošača u smislu popularnosti automobilskih marki. U razdoblju prije krize najprodavanija marka (u prosjeku za razdoblje 2005-2008) bio je Opel, dok je u razdoblju poslije i za vrijeme krize prvo mjesto prema broju novoregistriranih vozila zauzeo Volkswagen. Nadalje, skupina najprodavanijih automobila (mjerena brojem novoregistriranih automobila) nije se promijenila poslije 2008. u odnosu na onu prije 2008. U toj se skupini nalaze: Opel, Volkswagen, Renault, Peguot, Citroen i Škoda.

Grafikon 5: Prodaja automobila po markama u Hrvatskoj



Izvor: Izrada autora na osnovi podataka iz <http://www.autonet.hr/rubrika/hr-trziste>

Na grafikonu 5 prikazana je prodaja osamnaest najprodavanijih marki u Hrvatskoj. Može se primjetiti na većini marki drastičan pad prodaje, izuzev automobila prodajnih marki Honda, Dacia, Hyundai, Chevrolet.

Postavljaju se hipoteze.

H_0 : Prodaja automobila s obzirom na marku prije krize je jednaka istoj poslije i za vrijeme krize

H_1 : Prodaja automobila s obzirom na marku prije krize nije jednaka poslije i za vrijeme krize

Odnosno

$$H_0 \dots \eta_D = 0$$

$$H_1 \dots \eta_D \neq 0$$

Proveden je Wilcoxonov test na osnovi ekvivalentnih parova.

Slijedi opis postupka testiranja kod Wilcoxonovog testa na osnovi ekvivalentnih parova:

1. Izračunava se razlika između indeksa prodaje od 2005. godine do 2008. i od 2009. do 2013. godine.
3. Rangiraju se apsolutne razlike počevši od najmanje prema najvećoj uzimajući u obzir pojavu jednakih apsolutnih razlika kojima se pridružuje prosječan rang. U ovom primjeru se pojavljuju prosječni (vezani) rangovi.
4. Svakom rangui se daje onaj isti predznak koji je imala i razlika; ako je razlika pozitivna i rang je pozitivan, a ako je razlika negativna i rang je negativan.

Tablica 5 : Izračun razlika i rangova potrebnih za izračun testne veličine.

	2005.-2008.	2009.-2013.	Razlike ($y_i - x_i$)		Rang $y_i - x_i$
Opel	1	2	-1	-1	1
Renault	2	1	1	-1	1
Volkswagen	3	3	0	0	0
Peugeot	4	4	0	0	0
Škoda	5	6	-1	-1	1
Citroen	6	5	1	-1	1
Toyota	7	9	-2	-2	2
Ford	8	14	-6	-6	6
Fiat	9	7	2	-2	2
Hyundai	10	8	2	-2	2
Chevrolet	11	11	0	0	0
Mazda	12	10	2	-2	2
Seat	13	15	-2	-2	2
Suzuki	14	26	-12	-12	12
Mercedes	15	20	-5	-5	5
Audi	16	19	-3	-3	3
Honda	17	21	-4	-4	4
Kia	18	16	2	-2	2
bmw	19	12	7	-7	7
Nissan	20	13	7	-7	7
Dacia	21	18	3	-3	3
Lada	22	17	5	-5	5
Volvo	23	24	-1	-1	1
Alfa Romeo	24	25	-1	-1	1
Mitsubishi	25	22	3	-3	3
Smart	26	32	-6	-6	6
Land Rover	27	28	-1	-1	1
Subaru	28	30	-2	-2	2
Mini	29	27	2	-2	2
Chrysler	30	23	7	-7	7
Ssang Yong	31	31	0	0	0
Lancia	32	33	-1	-1	1
Lexus	33	37	-4	-4	4
Porsche	33	29	4	-4	4
Jaguar	35	34	1	-1	1
Saab	36	36	0	0	0
Dodge	37	39	-2	-2	2
Daihatsu	38	37	1	-1	1
Bentley	39	40	-1	-1	1
Chevrolet USA	39	35	4	-4	4
Cadillac	41	40	1	-1	1

Izvor: Izračun autora

5. Nakon toga zbraja se posebno rang s pozitivnim predznacima, a posebno rang s negativnim predznacima te se određuje test-veličina.

T_+ (zbroj pozitivnih rangova) iznosi 330.

T_- (zbroj negativnih rangova) iznosi 336.

6. Izračunava se očekivanje i standardna devijacija za Wilcoxonov test na osnovi ekvivalentnih parova:

- a) Očekivana vrijednost (uz pretpostavku istinite nulte hipoteze) Wilcoxonovog testa na osnovi ekvivalentnih parova jednaka je

$$\mu_T = \frac{n(n+1)}{4} = \frac{36 * 37}{4} = 333$$

- b) Standardna pogreška Wilcoxonovog testa na osnovi ekvivalentnih parova jednaka je:

$$\sigma_T = \sqrt{\frac{n(n+1)(2n+1)}{24}} = \sqrt{\frac{97236}{24}} = 63,65$$

- c) T test-veličina je empirijski z-omjer budući da je veličina uzorka veća od 20:

$$z = \frac{(T_0 + 0.5) - \mu_T}{\sigma_T} = \frac{318.5 - 333}{63.65} = -0.05$$

Test-veličina je $\min \{T_+, T_-\} = 330$

Tablica 6: Output microsoft excel

Wilcoxon Signed Rank Test	
variables:	rang prije - rang poslije
330	sum of positive ranks
336	sum of negative ranks
36	n
333,00	expected value
58,72	standard deviation
-0,05	z, corrected for ties
,9593	p-value (two-tailed)

Izvor: Vlastita izrada autora

Vrijednost testne statistike iznosi $z = -0.5$, a pripadna p-vrijednost 0.96. Stoga ne odbacujemo hipotezu H_0 . Dakle, rangovi automobilskih marki s obzirom na prodaju ne razlikuju se značajno u razdoblju prije i razdoblju poslije 2008. godine. Na isti zaključak navodi i Spearmanov koeficijent korelacije koji je jednak 0.95 koji sugerira kako postoji jaka pozitivna linearna veza između rangova automobilskih brandova prije, poslije i za vrijeme trajanja krize. Time se može zaključiti kako su unatoč krizi, rangovi automobilskih marki na hrvatskom tržištu ostali stabilni, to jest da se preferencije kupaca nisu promijenile unatoč krizi.

Tablica 7: Output microsoft excel


<i>Izvor: Vlastita izrada autora - Output microsoft excel</i>		
Spearman Coefficient of Rank Correlation		
	Prije	poslije
prije	1,000	
poslije	,952	1,000
41 sample size		
	± ,308	critical value .05 (two-tail)
	± ,398	critical value .01 (two-tail)

Izvor: Vlastita izrada autora

4.2. Usporedba prodaje automobila s obzirom na pogonsko gorivo

Usporedbom udjela novoregistriranih „dizelaša“ za 30 najprodavanijih marki u Republici Hrvatskoj vidljivo je kako 2013. zabilježen rast udjela novoregistriranih „dizelaša“ za većinu automobilskih marki u odnosu na razdoblja prije 2013. Na grafikonu 6 prikazan je udio novoregistriranih automobila na dizelski pogon za 15 najprodavanijih marki u RH.


Grafikon 6: udio novoregistriranih automobila na dizelski pogon za 15 najprodavanijih marki u RH



Izvor: Vlastita izrada autora

S druge strane, usporedbom udjela novoregistriranih „benzinaca“ za 30 najprodavanijih marki u Republici Hrvatskoj vidljivo je kako 2013. zabilježen pad udjela novoregistriranih „benzinaca“ za većinu automobilskih marki u odnosu na razdoblja prije 2013.. Na grafikonu sedam prikazan je udio novoregistriranih automobila na benzinski pogon za 15 najprodavanijih marki u RH.

Grafikon 7: Udio novoregistriranih automobila na benzinski pogon za 15 najprodavanijih marki u RH



Izvor: Vlastita izrada autora


Budući da se iz grafikona može očitati blagi pad udjela novoregistriranih „benzinaca“ za većinu automobilskih marki, od interesa je ispitati je li taj pad statistički značajan. Proveden je hi-kvadrat test o distribuciji. Ispitana je jednakost distribuiranosti prosječnih udjela novoregistriranih automobila pojedinih marki s obzirom na gorivo. U analizu su uzete 42 najprodavanije marke automobila (već nabrojane u prethodnom odjeljku). Zbog nedostupnosti podataka, u razdoblje prije krize uključeni su podaci samo iz 2007. i 2008. godine, dok su u razdoblje poslije (i za vrijeme) uključeni podaci iz razdoblja 2009.-2013. godine.

Postavljene su hipoteze:

H₀ : distribucija novoregistriranih automobila s pogonom na benzin unutar pojedine marke u razdoblju 2007-2008 je jednaka distribuciji novoregistriranih automobila s pogonom na benzin u razdoblju 2009-2013

H₁: distribucija nije jednaka

Grafikon 8: Usporedba udjela novoregistriranih automobila s pogonom na benzin prije, poslije (i za vrijeme) krize za 29 najprodavanijih marki



Izvor: Vlastita izrada autora

Vrijednost testne statistike iznosi 3.48, a pripadna p-vrijednost 1. Stoga, rezultati testa upućuju na neodbacivanje nulte hipoteze, tj. kako ne postoji statistički značajna razlika u distribuciji novoregistriranih automobila s pogonom na benzin unutar pojedinih marki u u promatranim razdobljima. To jest, distribucija udjela novoregistriranih „benzinaca“ je jednaka distribuciji udjela novoregistriranih „benzinaca“ unutar pojedinih marki u razdoblju 2009.-2013.

Tablica 8: Output microsoft excel

Goodness of Fit Test

observed	expected	O - E	$(O - E) / E$	% of chisq
0,7645	0,731	0,033	0,001	0,05
0,6865	0,600	0,087	0,013	0,39
0,2575	0,305	-0,048	0,008	0,23
0,6525	0,453	0,199	0,088	2,73
0,556	0,307	0,249	0,201	6,27
0,682	0,474	0,208	0,091	2,84
0,4875	0,636	-0,148	0,035	1,08
0,7485	0,602	0,147	0,036	1,11
0,7465	0,719	0,028	0,001	0,03
0,7795	0,826	-0,046	0,003	0,08
0,9295	0,843	0,086	0,009	0,27
0,7535	0,682	0,071	0,007	0,23
0,6605	0,569	0,092	0,015	0,46
0,961	0,965	-0,004	0,000	0,00
0,1835	0,104	0,080	0,061	1,89
0,8365	0,841	-0,004	0,000	0,00
0,2795	0,258	0,022	0,002	0,06
0,7225	0,736	-0,013	0,000	0,01
0,287	0,109	0,178	0,293	9,13
0,6595	0,630	0,029	0,001	0,04
0,804	0,684	0,120	0,021	0,66
0,3335	0,158	0,176	0,196	6,10
0,278	0,540	-0,262	0,127	3,97
0,6435	0,748	-0,105	0,015	0,45
0,96	0,960	0,000	0,000	0,00
0,938	0,720	0,218	0,066	2,07
0,921	0,241	0,680	1,919	59,79
0,486	0,516	-0,030	0,002	0,05
17,998	15,957	2,041	3,209	100,00

Warning: sums should be equal.

3,21

chi-square

27

Df

1,0000

p-value

Izvor: Vlastita izrada autora

Na isti zaključak navodi i Spearmanov koeficijent korelacije koji je jednak 0.748 i sugerira kako se udio novoregistriranih „benzinaca“, u pojedinoj marki automobila, kreće jednako prije, poslije i za vrijeme krize.

Tablica 9: Output microsoft excel

Spearman Coefficient of Rank Correlation		
	<i>b prije</i>	<i>b poslije</i>
<i>b prije</i>	1,000	
<i>b poslije</i>	,748	1,000
28 sample size		
	± ,374	critical value .05 (two-tail)
	± ,479	critical value .01 (two-tail)

Izvor: Vlastita izrada autora


Analogno analizi distribuiranosti novoregistriranih „benzinaca“, uspoređena je distribuiranost novoregistriranih automobila s pogonom na dizel unutar pojedinih marki u razdoblju prije krize, 2007-2008, te poslije i za vrijeme krize. Budući da novoregistrirani automobili na benzin i dizel čine gotovo 100% ukupnih novoregistriranih automobila, unaprijed se može zaključiti kako će i rezultati analize „dizelaša“ ukazivati na nepostojanje značajne razlike u distribuciji prije, poslije i za vrijeme krize. Ipak, dalje su prikazani statistički testovi, to jest rezultati testova i analiza.

Postavljene su hipoteze:

H₀ : distribucija udjela novoregistriranih automobila s pogonom na dizel unutar pojedine marke u razdoblju 2007-2008 je jednaka distribuciji udjela novoregistriranih automobila s pogonom na dizel unutar pojedinih marki u razdoblju 2009-2013

H₁: distribucija nije jednaka

Grafikon 9: Usporedba prodaje novoregistriranih automobila s pogonom na dizel prije, poslije i za vrijeme krize



Izvor: Vlastita izrada autora

Proveden je Wilcoxonov test na osnovi ekvivalentnih parova. Vrijednost testne statistike iznosi 1.39, a pripadna p-vrijednost 1. Stoga, rezultati testa upućuju na neodbacivanje nulte hipoteze, tj. kako ne postoji statistički značajna razlika u distribuciji. To jest, može se zaključiti kako je udio novoregistriranih automobila s pogonom na dizel u razdoblju 2007-2008 jednak distribucija novoregistriranih automobila s pogonom na dizel u razdoblju 2009-2013.

Tablica 10: Output micrisift excel

Goodness of Fit Test					
observed	expected	O - E	(O - E) / E	% of chisq	
0,2355	0,269	-0,033	0,004	0,29	
0,3135	0,400	-0,087	0,019	1,35	
0,7425	0,695	0,048	0,003	0,24	
0,3475	0,547	-0,199	0,073	5,22	
0,444	0,693	-0,249	0,089	6,41	
0,318	0,526	-0,208	0,082	5,91	
0,5125	0,364	0,148	0,060	4,33	
0,2515	0,398	-0,147	0,054	3,88	
0,2535	0,281	-0,028	0,003	0,20	
0,2205	0,174	0,046	0,012	0,88	
0,0705	0,157	-0,086	0,047	3,40	
0,2465	0,318	-0,072	0,016	1,16	
0,3395	0,431	-0,092	0,019	1,40	
0,039	0,035	0,004	0,001	0,04	
0,8165	0,896	-0,080	0,007	0,51	
0,1635	0,159	0,004	0,000	0,01	
0,7205	0,742	-0,022	0,001	0,04	
0,2775	0,264	0,013	0,001	0,05	
0,713	0,891	-0,178	0,036	2,57	
0,3405	0,370	-0,029	0,002	0,16	
0,196	0,316	-0,120	0,046	3,28	
0,6665	0,842	-0,176	0,037	2,64	
0,722	0,460	0,262	0,150	10,77	
0,3565	0,251	0,106	0,045	3,22	
0,04	0,040	0,000	0,000	0,00	
0,062	0,280	-0,218	0,170	12,23	
0,079	0,559	-0,480	0,412	29,63	
0,514	0,479	0,035	0,003	0,18	
10,002	11,836	-1,834	1,391	100,00	
Warning: sums should be equal.					
1,39	chi-square				
27	Df				
1,0000	p-value				

Izvor: Vlastita izrada autora

Na isti zaključak navodi i Spearmanov koeficijent korelacije koji je jednak 0.748 i sugerira kako se udio novoregistriranih „dizelaša“, u pojedinoj marki automobila, kreće jednako prije i poslije (i za vrijeme) krize.

Tablica 11:Output microsoft excel

Spearman Coefficient of Rank Correlation		
	<i>d prije</i>	<i>d poslije</i>
<i>d prije</i>	1,000	
<i>d poslije</i>	,779	1,000
28 sample size		
	± ,374	critical value .05 (two-tail)
	± ,479	critical value .01 (two-tail)

Izvor: Vlastita izrada autora

5. Zaključak

S obzirom na činjenicu da je cijeli svijet zahvatila ekonomska kriza, odnosno dolaskom do velikog pada realnog dohotka, porasta nezaposlenosti te zbog niskog stupnja iskorištenosti proizvodnih kapaciteta, velik udarac ekonomske krize na automobilsku industriju bio je očekivan slijed događaja. Porast troškova života, snižene plaće, nezaposlenost, nepovoljni krediti su samo neki od razloga koji odvrćaju ljude od kupnje novih automobila. U strahu za daljnje zaposlenje i nepredvidivost budućnosti sve više ljudi se odlučuje na polovne automobile koji se, barem na prvi dojam, čine kao jeftinija opcija.

Tržište automobila u Hrvatskoj, kako novih, tako i rabljenih, određeno je različitim varijablama među kojima se u znanstvenoj i stručnoj literaturi uobičajeno analizira i jedna mikroekonomska varijabla, cijena naftnih derivata.

U radu je analiziran broj novoregistriranih osobnih automobila za četrdeset i dvije najprodavanije marke u razdoblju prije i poslije prijelomne 2008./2009. godine. Također, provedena je posebna analiza broja novoregistriranih automobila za, trideset najprodavanijih marki, s obzirom na pogonsko gorivo: dizel i benzin. U promatranom razdoblju došlo je do promjene u broju novoregistriranih automobila Tržište je raslo do 2008. godine, nakon čega je broj novoregistriranih automobila prepolovljen. Istovremeno se mijenjao i udio automobila s obzirom na pogonsko gorivo (benzin i dizel). Ukupni udio "benzinaca" od 2007.-2013. je porastao u odnosu na "dizelaše", a njihov broj unutar marki automobila kreće se u različitim omjerima po godinama. U radu je pokazano kako ne postoji statistički značajna razlika u distribuciji novoregistriranih automobila, unutar trideset najprodavanijih marki, s pogonom na benzin i s pogonom na dizel.

Ono što se može zaključiti iz brojčanih podataka i grafova da su automobilske marke više klase kao što su BMW, Mercedes, i one pristupačnije, niže klase kao što su Hyundai, Chevrolet zadržale konstantu, odnosno nisu zabilježile drastičan pad u krizi, štoviše, Kia je primjerice zabilježila porast u prodaji. Ipak, usporedbom popularnosti pojedinih marki u Republici Hrvatskoj (mjerene rangom prema broju novoregistriranih automobila), može se zaključiti kako ne postoji statistički značajna razlika u rangovima prije i poslije prijelomne 2008. godine. To jest, može se zaključiti kako su unatoč krizi, rangovi automobilskih marki na hrvatskom tržištu ostali stabilni, što navodi na zaključak kao se preferencije kupaca nisu promijenile unatoč krizi.

Popis grafikona, slika i tablica

Grafikon 1. Ukupan broj proizvedenih automobila u razdoblju od 2000. godine do 2011. Godine str.21.

Grafikon2. Najveći svjetski proizvođači automobila 2011. Godine str. 22.

Grafikon 3: Broj novoregistriranih automobila u Republici Hrvatskoj, str. 25.

Grafikon 4. Usporedba postotka automobila s pogonom na benzin i automobila s pogonom na dizel str. 25.

Grafikon 5. Prodaja automobila po markama u Hrvatskoj str. 29.

Grafikon 6. udio novoregistriranih automobila na dizelski pogon za 15 najprodavanijih marki u RH str. 34.

Grafikon 7. Udio novoregistriranih automobila na dizelski pogon za 15 najprodavanijih marki u RH str. 35.

Grafikon 8. Usporedba prodaje novoregistriranih automobila s pogonom na benzin prije, poslije, i za vrijeme krize str. 36.

Grafikon 9. Usporedba prodaje novoregistriranih automobila s pogonom na dizel prije, poslije i za vrijeme krize str. 39.

Slika 1. χ^2 -distribucije za stupnjeve slobode, $k = 1,2,3,4,6,9$ str. 17.

Slika 2. Granične vrijednosti varijable χ^2 za pripadne površine ispod krivulje i k stupnjeva slobode str. 18.

Tablica 1. Postupak testiranja i njegovi ishodi str. 6.

Tablica 2. Pravila odlučivanja na temelju P-vrijednosti str. 7.

Tablica 3. Hipoteze i područja prihvatanja i neprihvatanja nulte hipoteze str. 14.

Tablica 4. Output microsoft excel Wilcoxon Signed Rank Test str. 28.

Tablica5. Izračun razlika i rangova potrebnih za izračun testne veličine str. 31.

Tablica 6. Output microsoft excel Wilcoxon Signed Rank Test str. 32.

Tablica 7. Output microsoft excel Spearman Coefficient of Rank Correlation str. 33.

Tablica 8. Output microsoft excel Goodness of Fit Test str. 37.

Tablica 9. Output microsoft excel Spearman Coefficient of Rank Correlation str. 38.

Tablica 10. Output micrisift excel Goodness of Fit Test str. 40.

Tablica 11. Output microsoft excel Spearman Coefficient of Rank Correlation str. 41.

Literatura:

1. Aczel A, Sounderpandian J, *Complete Business Statistics*, McGraw-Hill international edition 2009.
2. Antončić Robert, *Automobil vlada svijetom*, Tisak Varteks, Varaždin, 2002.
3. Horvat J.; Mijoč J.; "Osnove statistike", str. 382., Ljevak, Zagreb, 2012.
4. Šošić I.; "Primijenjena statistika", str. 237., Školska knjiga, Zagreb, 2004.
5. Žužul Josip, Branica Marija, *Statistika*, Informator, Zagreb, 1998.
6. Arbanas Branimir, Bilas Vlatka, Franc Sanja, Utjecaj aktualne ekonomske krize nastajanje i perspektive razvoja autoindustrije, *Ekonomski misao i praksa*, XXII. (2013.), br. 1., (str. 299-320)
7. Grgić, M. i Bilas, V., *Međunarodna ekonomija*. Zagreb: Lares plus, 2008.
8. Haugh, D., Mourougana, A. i Chatal, O., 2010. The Automobile Industry in and Beyond the Crisis, *OECD Economics Department Working Papers*, No. 745 [pdf] dostupno na: <http://dx.doi.org/10.1787/5kmmmp8wg6cmq-en>
9. Kovačević Zoran, Ivan Šušnjar, Gelo Tomislav. Utjecaj kretanja cijena naftnih derivata na tržište automobila u Republici Hrvatskoj, *Ekonomski misao i praksa*, XXIII. (2014.) br. 1. (105-126) Zagreb, 2014.
10. Sturgeon, T. J. i Biesebroeck, J. V., 2010. Effects of the crisis on the automotive industry in developing countries, *Policy research working paper 5330*, *The World Bank* [pdf]
11. <http://dnevnik.hr/vijesti/hrvatska/ministarstvo-gospodarstva-u-utorak-posljednji-put-odredjuje-najvise-cijene-naftnih-derivata---323924.html>
12. http://www.unido.org/fileadmin/media/documents/pdf/Services_Modules/Automotive_Industry.pdf
13. http://www.unido.org/fileadmin/user_media/Publications/RSF_DPR/WP162009_Ebook.pdf
14. <http://oica.net/wp-content/uploads/industry-key-figures-oica-pressrelease>.
15. <http://polj.uns.ac.rs/Files/STATISTIKA/STATISITCKE%20METODE%20TEHNIKA-UREDZENJE%20VODA/140%20NEPARAMETARSKA%20STATISTIKA.pdf>;
16. <http://www.aik-invest.hr/sektori/automobilska-industrija/>
17. http://www.ehow.com/info_8587954_differences-between-parametric-nonparametric-tests.html#page=0; 3. travnja 2013. godine

18. http://www.globallabouruniversity.org/fileadmin/master_theses/South_Africa/Thesis_Mas_hilo.pdf

19. <http://www.autonet.hr/rubrika/hr-trziste>.

20. https://www.google.hr/url?sa=t&rct=j&q=&esrc=s&source=web&cd=1&ved=0CC4QFjAA&url=http%3A%2F%2Fwww.sumfak.unizg.hr%2Fdownload.aspx%3Ffile%3D%2FUpload%2Fsec_001%2Fins_002%2FBiometrika%2FTablica%2520hikvadrat%2520distribucije.pdf&ei=RPJFUbPmAcIMtQbbj4FQ&usg=AFQjCNHn7JfxcMqkQ-ZrdLwD2EFCcKeVYA&sig2=qIuOAKTqtFnNp8HQNHKQ1A&bvm=bv.43828540,d.

22. <http://www.ijf.hr/upload/files/file/newsletter/95.pdf>